

## 神經網理論에 의한 다목적 저수지의 홍수유입량 예측 Flood Inflow Forecasting on Multipurpose Reservoir by Neural Network

심 순 보\* / 김 만 식\*\* / 심 규 철\*\*\*

Shim, Soon Bo / Kim, Man Sik / Shim, Kyu Cheol

### Abstract

The purpose of this paper is to develop a neural network model in order to forecast flood inflow into the reservoir that has the nature of uncertainty and nonlinearity. The model has the features of multi-layered structure and parallel multi-connections. To develop the model, backpropagation learning algorithm was used with the Momentum and Levenberg-Marquardt techniques. The former technique uses gradient descent method and the later uses gradient descent and Gauss-Newton method respectively to solve the problems of local minima and for the speed of convergency. Used data for learning are continuous fixed real values of input as well as output to emulate the real physical aspects. After learning process, a reservoir inflows forecasting model at flood period was constructed. The data for learning were used to calibrate the developed model and the results were very satisfactory. Applicability of the model to the Chungju Multipurpose Reservoir proved the availability of the developed model.

*Keywords:* flood inflow forecast, multilayer neural network, multi-purpose reservoir,  
momentum technique, Levenberg-Marquardt Technique

### 요 지

본 논문의 목적은 다목적 저수지의 홍수유입량 예측을 위한 방법으로 竝列多重結線의 階層構造를 가진 신경망이론에 의하여 홍수시 불확실한 비선형시스템의 특성을 갖는 저수지 유입량 예측모형을 개발하는 것이다. 신경망이론을 이용한 예측모형의 개발을 위하여 역전파 학습알고리즘을 사용하였으며 역전파 학습알고리즘 사용시 흔히 대두되는 지역최소값 문제와 수렴속도의 향상을 위해서 최적화기법인 경사하강법을 이용한 모멘트법과 경사하강법과 Gauss-Newton 방법을 이용한 Leverberg-Marquardt법을 사용하였다. 모형개발에 사용된 자료는 연속적인 값으로 입력자료와 출력자료를 강우와 담유입량을 학습시킨 후, 저수지의 홍수유입량 예측을 위한 다층신경망 모형을 구성하였다. 학습시 사용한 자료를 토대로 개발된 모형을 검정한 결과 매우 만족스런 결과를 얻을 수 있었고 실제 충주댐 유역을 대상으로 저수지 홍수유입량 예측결과 모형의 타당성을 입증할 수 있었다.

핵심용어 : 홍수유입량예측, 다층신경망, 다목적저수지, 모멘트법, 레벤버그-마퀴트법

\* 충북대학교 공과대학 토목공학과 교수

\*\* 충북대학교 대학원 토목공학과 박사과정 수료

\*\*\* 미국 콜로라도주립대학교 대학원 토목공학과 박사과정 수료

## 1. 서 론

다목적댐 저수지를 홍수기에 효율적으로 운영하기 위해 선결되어야 할 필수적인 과제로 저수지 유입량의 정확한 예측을 할 수 있어야 한다. 수계내 저수지 유입수는 상류 수원부로부터 자연 상태의 유역 저류와 유출 특성, 그리고 하도 흐름의 추계학적, 동적 특성을 나타내면서 유입된다. 국내 다목적 저수지의 실용적 유입량 예측 기법인 저류함수법에 의한 유역 추적 및 하도추적 법이 있으나 홍수유입량의 극대 홍수 발생 시간과 그 규모의 예측에 많은 문제점을 가지고 있다.(심순보, 1997; Shim, 1994a, b)

유입량의 정확한 예측은 가장 직접적으로 영향을 미치는 강우 자료를 토대로 실시간 적용할 수 있는 예측 모형을 개발하여 활용함으로서 정확도를 향상시킬 수 있으며, 이에 대한 한 대안으로 站列多重結線의 階層構造를 가진 推定方法으로(김주환, 1993) 불확실한 비선형시스템의 모형화 및 재현이 가능한 신경망이론을 이용하여 유입량 예측을 시도하였다. 신경망이론을 이용한 강우-유출 모형 연구는 국내·외로 1990년 이후부터 연구가 활발히 진행되었다. 국외로는 French 등(1992)은 시·공간분포를 신경망모형의 입출력 자료로 구성하여 강우의 공간분포를 예측하였으며, Nachimuthu 등(1994)은 cascade-correlation 알고리즘을 이용한 신경망모형을 구축하여 유출량을 예측하였으며, Hsu 등(1995)은 강우-유출 과정을 신경망모형과 ARMAX 모형 그리고 SAC-SMA 모형을 적용시켜 비교·고찰하였다. 그리고 Anthony(1996)는 홍수기에만 관측하고 있는 강우-유출자료 이외에 비홍수기를 포함한 자료의 획득을 위하여 계속적으로 모의발생시킨 선행강우와 유출량과의 관계를 규명하기 위해 신경망모형을 이용하였다. 국내에서는 김주환(1992, 1993)이 신경망모형에 적용하여 홍수시의 日단위와 時단위의 하천유출량 예측 모형을 제시하였고, 오경두와 전병호(1994)는 미계측 유역의 강우-유출 시뮬레이션에 적용하였으며, 오남선과 선우중호(1996)는 다층신경망 모형을 구성하여 강우 예측에 적용한 바 있다.

본 논문의 목적은 다목적 저수지의 홍수유입량 예측의 정도를 높이기 위한 것으로 站列多重結線의 階層構造를 가진 신경망이론을 이용하여 홍수시에 불확실한 비선형시스템의 특성을 갖는 다목적 저수지의 유입량을 예측을 시도하기 위해 신경망모형을 구축하여 그 예측 능력 및 적용 가능성을 검토하고자 한다. 신경망학습을

위해 역전파알고리즘을 이용하였으며, 오차를 감소시키기 위해 Levenberg-Marquardt 최적화 기법을 이용한 방법과 모멘트와 적응학습률을 이용한 방법을 비교·고찰하였다. 모형의 검정과 타당성 입증을 위해 충주댐 유역에 적용하였다.

## 2. 신경망이론

### 2.1 개요

신경망이론은 인간의 두뇌와 같이 생각하고 판단하며, 인식할 수 있는 능력을 구현하기 위해 인간뇌의 정보처리 메커니즘을 수학적으로 표현한 이론으로서 다수의 원소가 동시에 작동하는 병렬 처리 기계처럼 하드웨어 및 소프트웨어적인 병렬 분산 처리를 하는 시스템이며, 다른 환경에 맞도록 변화시킬 수 있는 학습 능력을 가지고 있다. 또한, 모형 개발에 있어 특별한 구조나 매개 변수 설정, 자료의 변환 등이 필요치 않고 자료의 축척에 따라 학습을 통하여 모형의 예측 능력을 향상시킬 수 있다.(Haykin, 1994; Smith, 1993)

이러한 특징으로 임의성이 많은 영상 신호 처리, 패턴 인식, 시스템 제어, 예측 및 시계열분석, 최적화 등에 활발히 적용되고 있다. 그리고 최근에는 토목공학의 다양한 분야에 적용되고 있으며, 수공학분야에서는 강우예측, 유출량예측 등에 적용하였다(Flood와 Kartam, 1994a, b).

### 2.2 다층신경망모형

다층신경망모형은 입력자료를 받아들이는 입력층(input layer), 결과를 나타내는 출력층(output layer), 그리고 두 층 사이에 은닉층(hidden layer)으로 구성되어 있으며, 이 층들을 결합하는 결선을 시냅스(synapse)라 하고 이 시냅스의 연결 강도(또는 결합 강도) 변화에 따라 입력에 따른 출력이 결정되어 진다(Haykin, 1994). 다층신경망모형에서 시냅스의 연결 강도는 모델에 따라 미리 계산에 의해 주어지는 경우와 학습에 의해 결정되는 경우가 있으며, 본 연구에서는 임의의 초기값에서 계속적인 개선이 이루어지며, 입출력시스템에 대해서 원하는 동작을 수행할 수 있도록 연결 강도를 최적의 상태로 적용시키는 학습과정(learning process)을 사용하였다.

학습 방식에 따라 지도 학습(supervised learning) 모형과 자율 학습(unsupervised learning) 모형으로 나눌 수 있으며, 입력 자료와 출력 자료가 이진수(binary)의 형태를 가지거나 실수 형태의 연속적인 값

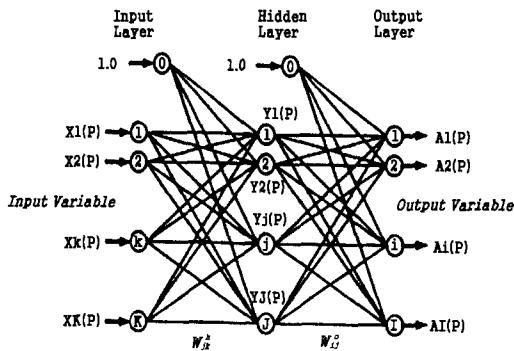


그림 1. 다층신경망 구조

을 가지는 두 가지 형태로 나누어지는데, 본 연구에서는 학습을 위해 입력 자료와 출력 자료로 이용되는 경우 자료와 유입량 자료가 실수 형태의 연속적인 값으로 존재하며 이 기준의 자료를 이용하는 지도 학습을 이용하였다.

본 연구에 적용된 다층신경망(multilayered neural network) 모형은 하나 이상의 은닉층이 존재하는 모형으로서 그림 1에 다층신경망 모형을 제시하였으며, 이 모형은 실수 형태의 자료에 대하여 지도 학습을 실시할 수 있으며 비선형 함수를 모의할 수 있다.

그림 1에서 입력층 성분들을  $X_k$ , 은닉층 성분들은  $Y_j$ , 그리고 출력층 성분들은  $O_i$ 로 나타내었으며, 입력층에서 은닉층으로의 연결 강도는  $W_{jk}^h$ , 은닉층에서 출력층으로의 연결 강도는  $W_{ij}^o$ 로 표시하였다. 입력층에서 은닉층이  $j$  번째 성분일 때  $X_k^j$ 라 하면, 입력 자료의 서로 다른 패턴을 위 첨자  $p$ 로 구분하여 몇 번째 입력 자료인지를 나타내며,  $k$ 는 입력층 뉴런을 나타낸다.

은닉층은 식 (1)과 같이 나타낼 수 있다.

$$Y_j^p = g(h_j^p) = g(\sum_{k=1}^K W_{jk}^h X_k^p + \theta_j) \quad (1)$$

여기서  $j$ 는 은닉층 뉴런( $1, \dots, j$ ),  $\theta_j$ 는 은닉층의  $j$  번째 성분의 임계값(threshold value),  $g$ 는 전달함수(transfer function),  $h_j^p$ 는 은닉층의  $j$  번째 성분의 입력패턴이다.

출력층은 식 (2)와 같이 나타낼 수 있다.

$$O_i^p = g(h_i^p) = g(\sum_{j=1}^J W_{ij}^o Y_j^p + \theta_i) \quad (2)$$

여기서  $i$ 는 출력층 뉴런( $1, \dots, i$ ),  $\theta_i$ 는 출력층의  $i$  번째 성분의 임계값(threshold value)이다.

다층신경망모형에서는 입력층에서 은닉층으로 또는

은닉층에서 출력층으로 연결될 때 연결 강도의 벡터들과 곱해져서 특정한 출력 함수를 거쳐 출력을 내게 되는데 이때 사용하는 출력 함수(또는 전이함수)는 대표적인 비선형 함수이며 가장 많이 사용되는 시그모이드(sigmoid)함수를 사용하였으며, 식 (3)과 같이 정의할 수 있다(김대수, 1994; Haykin, 1994).

$$g(x) = \frac{1}{1 + \exp(-x)} \quad (3)$$

또한, 도함수는 식 (4)와 같이 나타낼 수 있다.

$$g'(x) = g(x)(1 - g(x)) \quad (4)$$

### 2.3 역전파 알고리즘

다층 구조의 신경망에서 각 뉴런과 각 층(layer)의 모든 뉴런에 임계값(threshold values) 사이에 연결 최적화를 주기 위해서 학습 알고리즘(learning algorithm)이 필요하다. 본 연구에서는 학습 알고리즘으로 러멜하트(Rumelhart, 1986) 등에 의해 제안된 역전파 알고리즘(backpropagation algorithm)을 사용하였다. 역전파 알고리즘은 입력층의 각 유니트에 입력패턴이 주어지면 이 신호는 각 유니트에서 가중값에 의해 변환되어 은닉층에 연결되고 마지막에 출력층으로 전파해 나가는데, 이때 네트워크에서 출력된 신호 패턴이 목표 패턴과 일치하지 않을 경우 역방향인 출력 패턴에서 목표 패턴으로 오차의 값을 감소시킬 수 있도록 네트워크의 연결 강도를 조절하여 학습하는 방법으로, 학습 후의  $W_{ij}$ (은닉층과 출력층 사이의 연결 강도)와  $\theta_i$ (출력 뉴런의 임계값)은  $\Delta W_{ij}$ 와  $\Delta \theta_i$ 의 계산에 의해 갱신되며, 다음으로  $W_{jk}$ (입력층과 은닉층 사이의 연결강도)와  $\theta_j$ (은닉 뉴런의 임계값)은  $\Delta W_{jk}$ 와  $\Delta \theta_j$ 에 의해 갱신된다. 일반적으로 역전파 알고리즘은 주어진 입력과 출력에 대한 연결강도를 구하기 위해 오차(목적)함수를 이용하며 식 (5)와 같다.

$$E(W') = \frac{1}{2} \sum_{i=1}^I (\xi_i - O_i)^2 \quad (5)$$

여기서  $i$ 는 기대 출력값,  $O_i$ 는 계산 출력값이다.

#### 2.3.1 모멘트(momentum)법과 적응학습률(adaptive learning rate)

학습 과정에서 발생할 수 있는 지역최소값(local minima value) 문제와 오차를 적게 해서 수렴 속도를 빨리하여 학습 속도를 향상시키기 위해 최적화 기

법인 경사하강법(gradient descent method)을 사용하였다.

입력층에서 은닉층으로의 연결강도  $W_{jk}$ 와 은닉층에서 출력층으로의 연결강도  $W_{ij}$ 의 조절량은 식 (6)과 식 (7)에 나타내었다.

$$W_{jk}(t+1) = W_{jk}(t) + \mu \delta_j^h X_j \quad (6)$$

$$W_{ij}(t+1) = W_{ij}(t) + \mu \delta_i^o Y_j \quad (7)$$

그리고 임계값  $\theta$ 는 식 (8), 식 (9)와 같다.

$$\theta_i(t+1) = \theta_i(t) - \mu \delta_{io} \quad (8)$$

$$\theta_j(t+1) = \theta_j(t) - \mu \delta_{jh} \quad (9)$$

윗식에서  $\mu$ 는 학습률(learning rate)로서 1보다는 작은 값을 가지며,  $\delta_i^o$ 과  $\delta_j^h$ 는 전달함수의 미분 형태와 오차의 곱으로 이 항을 조절하면서 오차를 줄여 나가며 식 (10), 식 (11)과 같다.

$$\delta_i^o = g'(h_i)[X_i - O_i] \quad (10)$$

$$\delta_j^h = g'(h_j) \sum_{i=1}^l \delta_i^o W_{ij} \quad (11)$$

다중신경망모형에서 역전파 알고리즘에 의한 학습 과정에서 발생할 수 있는 지역최소값(local minima value)문제와 오차를 적게 하고, 수렴 속도를 빨리하여 학습 속도를 향상시킬 수 있는 모멘트(momentum)법과 적응학습률(adaptive learning rate)을 사용하였다. 모멘트(momentum)법은 간단하면서도 효율적이기 때문에 자주 이용되는 방법으로 모멘트항을 학습에 포함시키며 이에 대한 수식은 식 (12), 식 (13)과 같다.

$$\Delta W_{ij}(t+1) = \Delta W_{ij}(t+1) + \alpha \Delta W_{ij}(t) \quad (12)$$

$$\Delta W_{jk}(t+1) = \Delta W_{jk}(t+1) + \beta \Delta W_{jk}(t) \quad (13)$$

여기서,  $\alpha$ 와  $\beta$ 는 연결강도  $W_{jk}$ 와  $W_{ij}$ 의 모멘텀(momentum) 계수로서 0에서 1 사이의 값을 가지며, 주로 0.90~0.95의 값을 이용하는데 본 연구에서는 0.95를 사용하였다. 적응학습률(adaptive learning rate)은 모멘트 방법과 병행하여 학습률  $\mu$ 를 조절하며 학습 속도를 향상시킨다. 학습 후에 오차 험수가 감소하였나 확인을 하여 크게 감소하였을 때에는 학습률을 일정 비율만큼 증가시키고, 반대로 오차 험수가 정해진 비율에 이상으로 증가하였을 때에는 학습률을 정해진 비율만큼 감소시키게 되며, 수식으로 나타내면 식 (14)와 같다.

$$\mu(t+1) = \begin{cases} r_1 \mu(t) & E(t+1) < E(t) \\ r_2 \mu(t) & E(t+1) > r_3 E(t) \\ \mu(t) & \text{otherwise} \end{cases} \quad (14)$$

여기서 매개변수  $r_1$ ,  $r_2$ ,  $r_3$ 를 일반적으로 사용하는 1.04, 0.7, 1.05 값을 이용하였으며, 학습률 초기값은 0.01로 하였다.

### 2.3.2 Levenberg-Marquardt 방법

역전파 알고리즘에 의한 학습 과정에서 발생할 수 있는 지역최소값(local minima value)문제와 오차를 적게 해서 수렴 속도를 빨리하여 학습 속도를 향상시키기 위해 본 연구에서는 출력값의 SSE(Sum of Square Error)를 최소화하는 최적 기법으로 Levenberg-Marquardt 방법을 이용하였다. 이 방법은 연결강도를 조정할 때 Levenberg-Marquardt 생신률을 사용하게 되는데 행렬 형식으로 된 Levenberg-Marquardt 생신률은 식 (15)와 같다(Demuth 외 Beale, 1994).

$$\Delta W = (J^T J + \mu I)^{-1} J^T e \quad (15)$$

여기서  $J$ 는 각 연결강도에 대한 오차 미분의 Jacobian matrix,  $\mu$ 는 스칼라(scalar),  $e$ 는 오차벡터(error vector)이다. 식(15)에서  $\mu$ 가 매우 크면 경사하강법(gradient descent)으로 근사되고,  $\mu$ 가 작으면 가우스-뉴턴(Gauss-Newton)방법으로 근사되는데, 가우스-뉴턴 방법은 오차공간상(error surface)의 오차가 최소인 시점 근방에서 다른 방법에 비하여 더 빠르고 정확하게 이 시점으로 수렴해 나간다. 따라서 적응학습률에서  $\mu$ 를 조정하여 가능하면 가우스-뉴턴방법으로 근사하도록 한다. 이 방법 외에도 역전파 알고리즘의 단점을 개선하기 위해 은닉층의 유니트수를 증가시키거나 연결강도의 초기값을 여러가지 임의(random)수를 주어 학습시키는 방법이 있으나(김대수, 1994; 윤여창, 1995; Smith, 1993; Haykin, 1994) 아직까지 확기적인 방법은 개발되지 못한 형편이다. 그러나 Levenberg-Marquardt update rule 방법은 다른 방법에 비해 많은 시간과 메모리를 필요로 하는 단점도 있으나, 고성능 컴퓨터에서 운영할 경우 큰 문제가 되지 않는 것으로 사료된다.

## 3. 유입량 예측 모형

본 연구에서는 유입량 예측을 위해 입력층에는 선행 강우자료와 댐유입량자료를, 출력층에는 현재시점의 댐유입량자료를 이용하였고, 일반적으로 시간의 흐름에

따른 비선형 강우-댐유입량의 관련성은 식 (16)과 같이 정의할 수 있다.

$$I(t+1) = f[R(t-k), I(t-k)] \text{ for } k=0,..,n \quad (16)$$

여기서  $I(t+1)$ 는 1시간 후의 댐 예측유입량,  $R(t)$ 는 주어진 총 강우량,  $I(t-k)$ 는  $k$ 시간 전의 댐유입량,  $k$ 는  $n$ 간격의 지체시간(시간, 일, 달, 년)이다.

식 (16)을 이용하여 다층신경망 모형에 적용한 방정식은 식 (17)과 같이 나타낼 수 있다.

$$X(t+1) = f\left(\sum_{j=1}^J W_j g\left(\sum_{k=1}^K W_{jk} (Y(t-k) + \theta_j) + \theta_k\right)\right) \quad (17)$$

여기서  $X(t+1)$ 는 예측 댐유입량,  $Y(t-k)$ 는 학습된 시계열(강우, 댐유입량),  $W_j$ 는 은닉층과 출력층사이의 가중치(연결강도),  $W_{jk}$ 는 은닉층과 입력층사이의 가중치(연결강도),  $\theta_j$ 는 은닉층의 임계값(threshold value),  $\theta_k$ 는 입력층의 임계값,  $f()$ ,  $g()$ 는 시그모이드 함수(sigmoid function)  $k$ 는 1시간 간격의 지체시간이다.

본 연구의 댐유입량 예측모형은 식 (17)을 이용하여 두 가지 방법에 의한 다층신경망 모형을 구축하였으며, 전달함수로는 시그모이드(sigmoid)를 사용하였다. 학습 방법은 역전파알고리즘을 이용하였다. 그림 2는 강우-댐유입량 예측 모형을 위한 역전파 알고리즘을 이용한 다층신경망의 구조를 나타내었다.

## 4. 적용 및 고찰

### 4.1 유역현황

본 연구의 적용 대상인 충주댐 유역은 유역 면적이 한강 수계 전체 유역 면적의 약 25%에 해당하는  $6,648\text{km}^2$ 로서 남한강 유역 면적의 53%에 상당한다. 서울로부터 150km 상류인 남한강에 본댐이 위치하고 있고, 연평균 유입량은  $5,220 \times 10^6\text{m}^3$ 에 달한다(한국수자원공사, 1992). 그래서 충주댐 유역은 한강 유역에 홍수 피해 경감과 용수 공급에 큰 영향을 미치는 중요한 유역으로서 강우 관측소는 34개 지역에 있다.

### 4.2 대상홍수 선정

본 연구에서 구축한 다층신경망 모형의 학습을 위해 선정한 홍수 강우 사상은 15개로 1시간에 34개지역의 총 면적 강우량이  $3,000\text{mm/hr}$ 에서  $10,000\text{mm/hr}$ 를 나타났으며, 선정한 강우 사상은 표 1과 같다.

### 4.3 적용

구축된 강우-댐유입량 예측 모형을 충주댐 유역에 적용하여 그 예측 능력 및 가능성을 검토하였다. 충주댐 저수지 유입 지점 상류에 위치해 있는 T/M 우량국들로부터 1시간 단위의 강우 자료와 저수지 유입량 자료를 사용하여 홍수기에 댐유입량 예측을 시도하였다. 신경망모형의 학습을 위해 입력 자료와 출력 자료는 한강홍

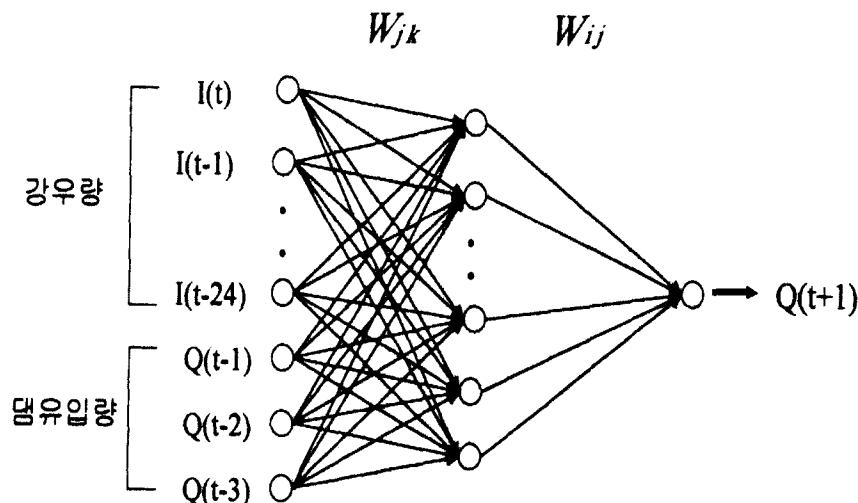


그림 2. 강우-댐유입량 모형을 위한 다층신경망 구조

**표 1. 충주댐 저수지 유역의 선정된 홍수 강우사상**

번호	홍수 강우사상 기간
1	1987년 7월 15일 16시 - 18일 18시
2	1987년 7월 21일 12시 - 25일 11시
3	1987년 7월 25일 17시 - 30일 20시
4	1987년 8월 3일 15시 - 7일 14시
5	1987년 8월 28일 18시 - 9월 03일 07시
6	1988년 7월 13일 13시 - 18일 06시
7	1988년 7월 19일 19시 - 22일 22시
8	1989년 7월 25일 17시 - 8월 01일 01시
9	1990년 6월 24일 19시 - 28일 05시
10	1991년 7월 20일 08시 - 21일 15시
11	1992년 8월 27일 13시 - 29일 19시
12	1993년 7월 13일 01시 - 15일 19시
13	1993년 8월 08일 13시 - 13일 23시
14	1994년 7월 07일 10시 - 08일 13시
15	1994년 8월 28일 19시 - 30일 13시

수통제소와 한국수자원공사의 34개 지역 강우 관측소 자료와 충주댐 유입량 자료를 사용하였다. 1987년부터 1994년까지의 34개 강우 관측소 지역에 15개 홍수 사상을 선정하였으며, 이 기간의 강우 자료와 저수지 유입량 자료를 분석해 본 결과 선행 강우의 형태에 따라 짧게는 10시간에서 길게는 24시간까지의 지체 시간을 가지고 저수지 유입량에 영향을 미치는 것으로 나타났다. 그래서 선행 강우 24시간 전의 강우 자료에서 1시간 간격으로 현재 시간의 강우 자료까지 24개 계열과 선행 댐유입량의 영향도 받으므로 3시간 전까지의 댐유입량계열로 입력층을 구성하였다. 출력 자료로는 15개의 홍수 사상이 일어난 시기의 충주댐 저수지 유입량 자료를 사용하였다. 이와 같이 입력층과 출력층을 구성하여 은닉층노드 수와 학습

횟수에 변화를 주어 여러 가지의 다층신경망 모형을 구성하였다. 학습시킨 후, 유입량 예측을 행할 수 있는 다층신경망 모형으로 구성하여 모형의 검정을 위해 학습에 이용되지 않은 1995년 홍수유입량에 대한 예측을 시행하였다.

#### 4.4 결과 및 고찰

유입량 예측을 위한 다층신경망 모형의 수행 결과를 통계 분석하여 표 2에 나타냈으며, 은닉층의 개수 결정은 방법①에서는 12개 이상을 했을 때 보다 나쁜 결과를 나타냈기 때문에 개수를 줄여가며 수행했으며, 방법②에서는 입력층 성분이  $N$ 일 때 은닉층 개수를  $N$ 개부터  $4N$ 까지 수행하였다. 그리고 학습 회수는 각 방법에 따라 100회에서 50,000회까지 수행하였으며, 방법①은 1,500회 이상, 방법②는 25,000 이상에서는 모형의 성능 향상이 거의 없었다. 오차는 거의 대부분 학습 회수 100회 이내에서 급격히 감소하였으나 학습 회수가 적을 경우 예측의 정도가 매우 낮은 결과를 나타냈으므로 적당한 학습 회수를 주어 운영하였다. 표 2의 방법①과 ②에서 6가지 모형을 선정하여 그림 3~10에 추정 결과를 나타내었으며, 표 3에는 표 2에서 정확도 평가에 사용된 통계지표의 물리적 의미를 나타내었다.

15개의 강우사상을 이용해 댐유입량을 모의 과정에서 구해진 최적 매개변수를 이용하여 구성된 다층신경망 모형의 검정을 위해 학습에 이용되지 않은 1995년 8월 20일 04시부터 29일 15시까지의 홍수유입량을 예측한 결과를 그림 11과 표 4에 나타내었다. 방법①은 방법②보다 통계분석에서 오차가 적게 나왔으나 실제 예측한 결과는 표 4에서와 같이 조금 떨어지는

**표 2. 다층신경망 모형의 통계분석**

방법	구분	은닉층 노드	학습 회수	SSE	CC	RMSE	RMSPE	ME	MPE	MAD	MAPE
Levenberg-Marquardt ①	LM-1	5	1,500	0.512	0.991	0.029	8.655	0.000369	-0.248	0.018	4.231
	LM-2		500	0.490	0.992	0.029	8.339	0.000315	-0.239	0.018	4.189
	LM-3	8	1,500	0.408	0.993	0.026	7.496	0.000297	-0.215	0.017	4.065
	LM-4		500	0.378	0.994	0.025	7.160	0.000235	-0.206	0.017	3.959
	LM-5	10	1,500	0.343	0.994	0.024	5.816	0.000255	-0.167	0.015	3.597
	LM-6		500	0.301	0.995	0.023	6.467	0.000334	-0.186	0.015	3.629
	LM-7	12	1,500	0.281	0.995	0.022	5.262	0.000212	-0.151	0.014	3.220
	LM-8		500	0.332	0.994	0.023	5.868	0.000239	-0.168	0.016	3.704
momentum & adaptive learning rate ②	MA-1	15	25,000	0.821	0.986	0.035	11.951	0.000570	-0.343	0.022	5.021
	MA-2		20,000	0.842	0.986	0.036	12.225	0.000602	-0.351	0.022	5.090
	MA-3	30	25,000	0.789	0.987	0.035	12.050	0.000570	-0.346	0.022	5.104
	MA-4		20,000	0.802	0.983	0.039	15.871	0.001176	-0.456	0.025	5.665
	MA-5	45	25,000	0.788	0.981	0.040	15.972	0.000470	-0.458	0.026	5.886
	MA-6		20,000	0.825	0.986	0.035	12.841	0.000811	-0.369	0.023	5.318
	MA-7	60	25,000	0.737	0.988	0.034	12.272	0.000900	-0.352	0.022	4.974
	MA-8		20,000	0.768	0.987	0.034	12.597	0.000962	-0.362	0.022	5.069

표 3. 통계지표

항 목	관련식	비 고
SSE(오차제곱합)	$\frac{1}{N} \sum_{i=1}^N (X_i - Y_i)^2$	
CC(상관계수)	$\frac{1}{N} \sum_{i=1}^N \left( \frac{X_i - \bar{X}_i}{\sigma_X} \right) \left( \frac{Y_i - \bar{Y}_i}{\sigma_Y} \right)$	
RMSE(평균제곱오차)	$\sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - Y_i)^2}$	$X_i$ : 관측치 $Y_i$ : 계산치
RMSPE(평균제곱백분비오차)	$\sqrt{\frac{1}{N} \sum_{i=1}^N \left( \frac{X_i - \bar{Y}_i}{\bar{X}_i} \right)^2} \times 100$	$\bar{X}_i$ : 관측치 평균 $\bar{Y}_i$ : 계산치 평균
ME(평균오차)	$\frac{1}{N} \sum_{i=1}^N (X_i - Y_i)$	$\sigma_X$ : 관측치 표준편차 $\sigma_Y$ : 계산치 표준편차
MPE(평균백분비오차)	$\frac{1}{N} \sum_{i=1}^N \left( \frac{X_i - Y_i}{\bar{X}_i} \right) \times 100$	$N$ : 자료의 개수
MAD(평균절대편차)	$\frac{1}{N} \sum_{i=1}^N  X_i - Y_i $	
MAPE(평균절대백분비편차)	$\frac{1}{N} \sum_{i=1}^N \frac{ X_i - Y_i }{\bar{X}_i} \times 100$	

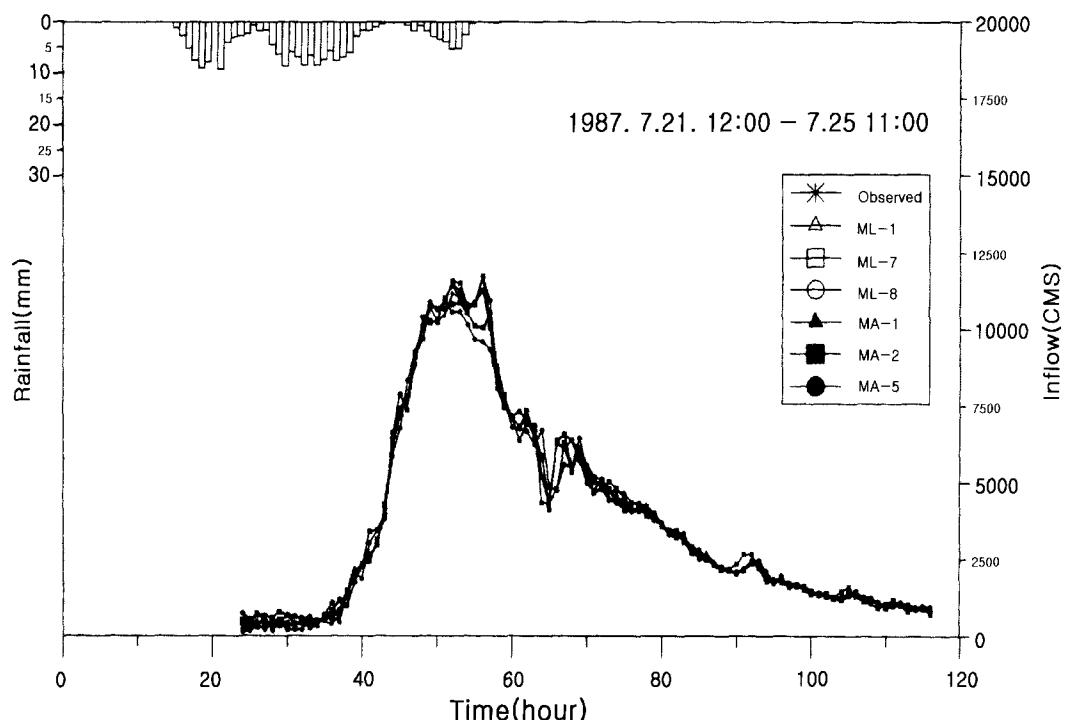


그림 3. 1987. 7. 21. 12:00 – 7. 25. 11:00 기간의 모의결과

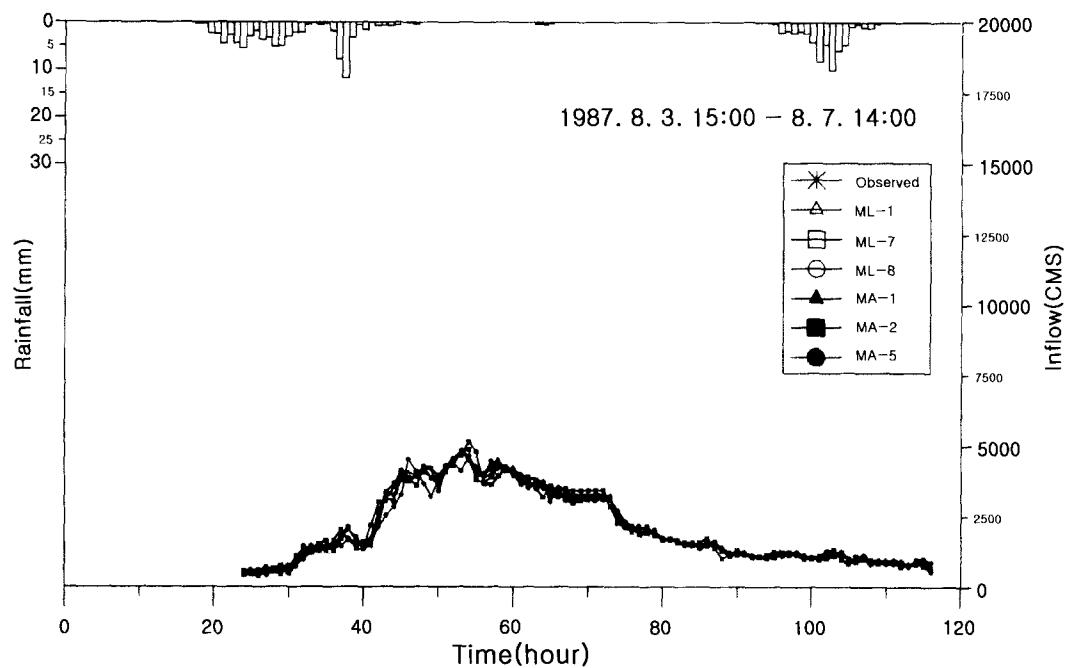


그림 4. 1987. 8. 03. 15:00 – 8. 07. 14:00 기간의 모의결과

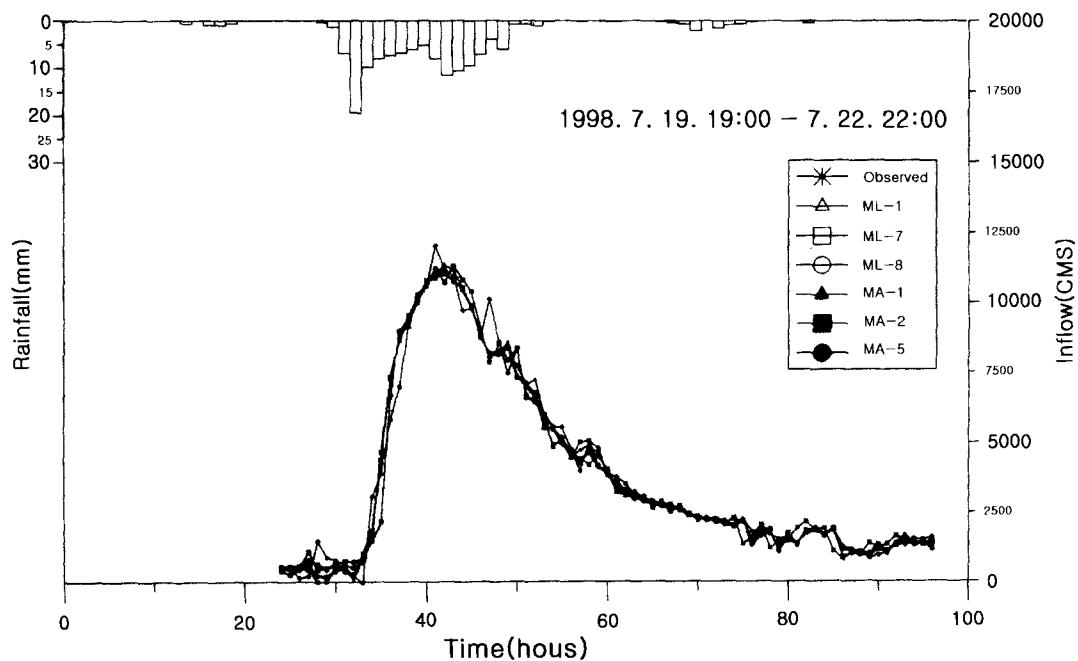


그림 5. 1988. 7. 19. 19:00 – 7. 22. 22:00 기간의 모의결과

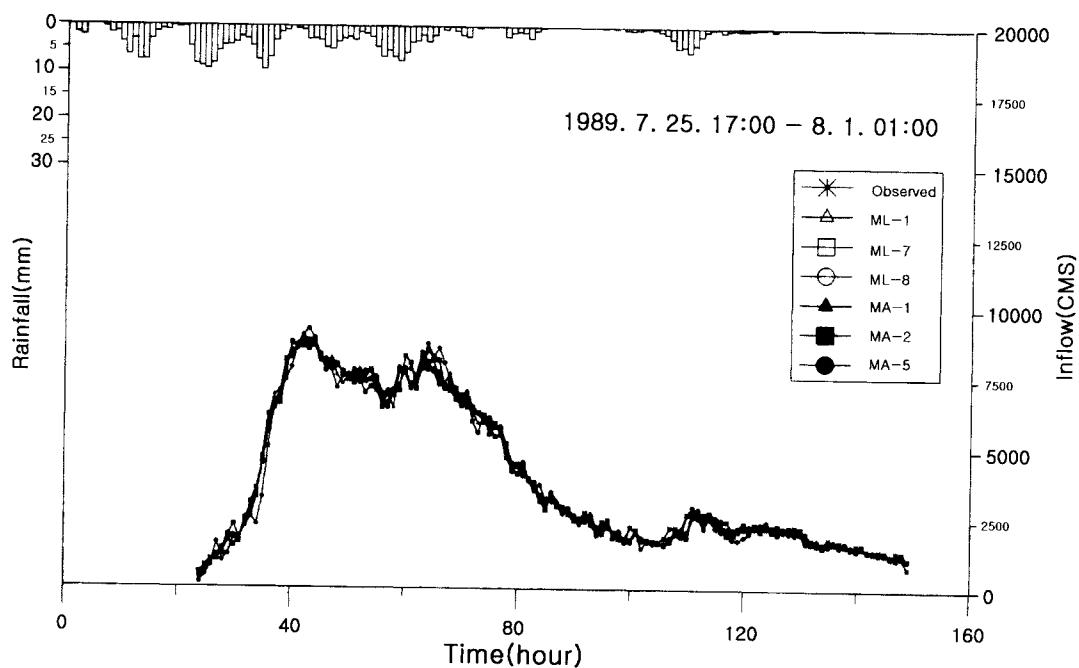


그림 6. 1989. 7. 25. 17:00 – 8. 01. 01:00 기간의 모의결과

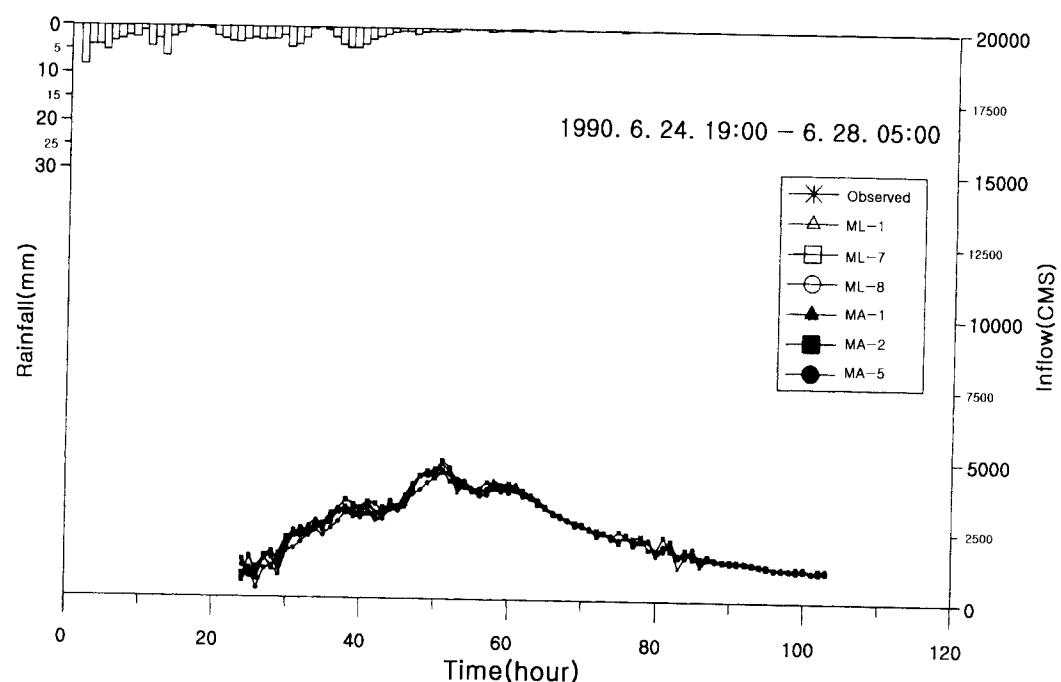


그림 7. 1990. 6. 24. 19:00 – 6. 28. 05:00 기간의 모의결과

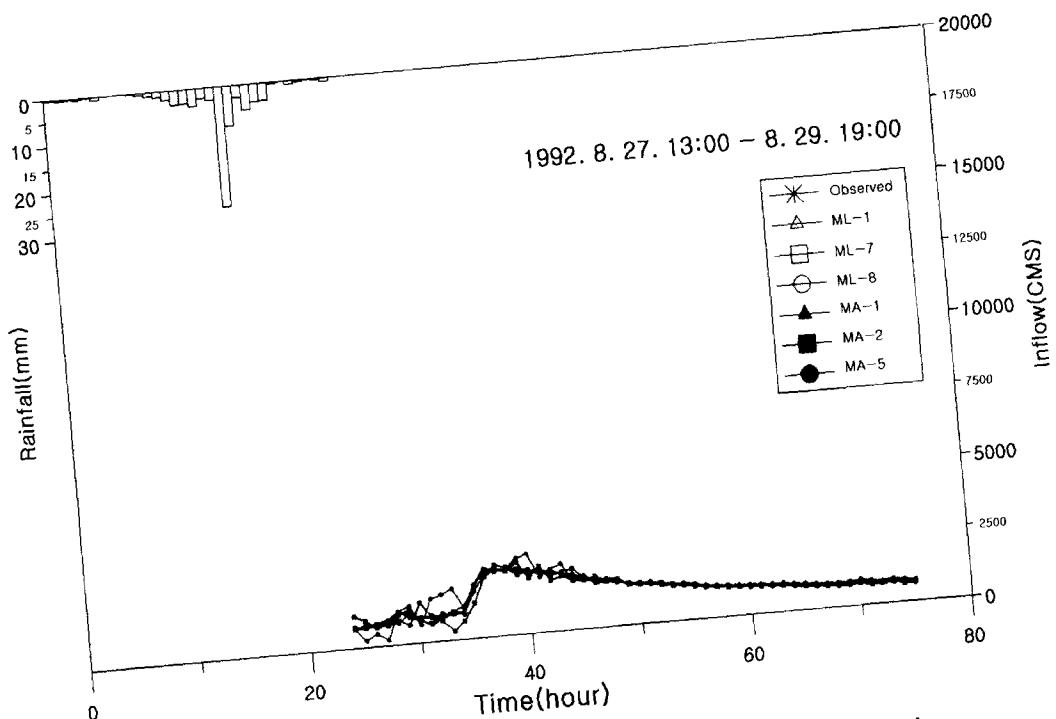


그림 8. 1992. 8. 27. 13:00 – 8. 29. 19:00 기간의 모의결과

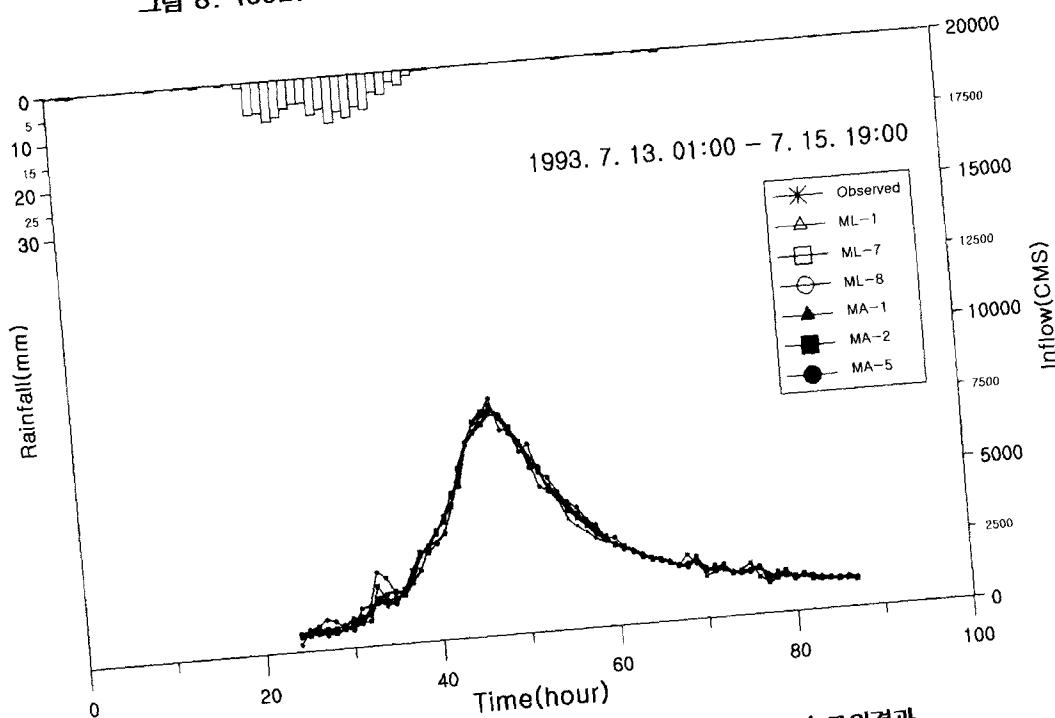


그림 9. 1993. 7. 13. 01:00 – 7. 15. 19:00 기간의 모의결과

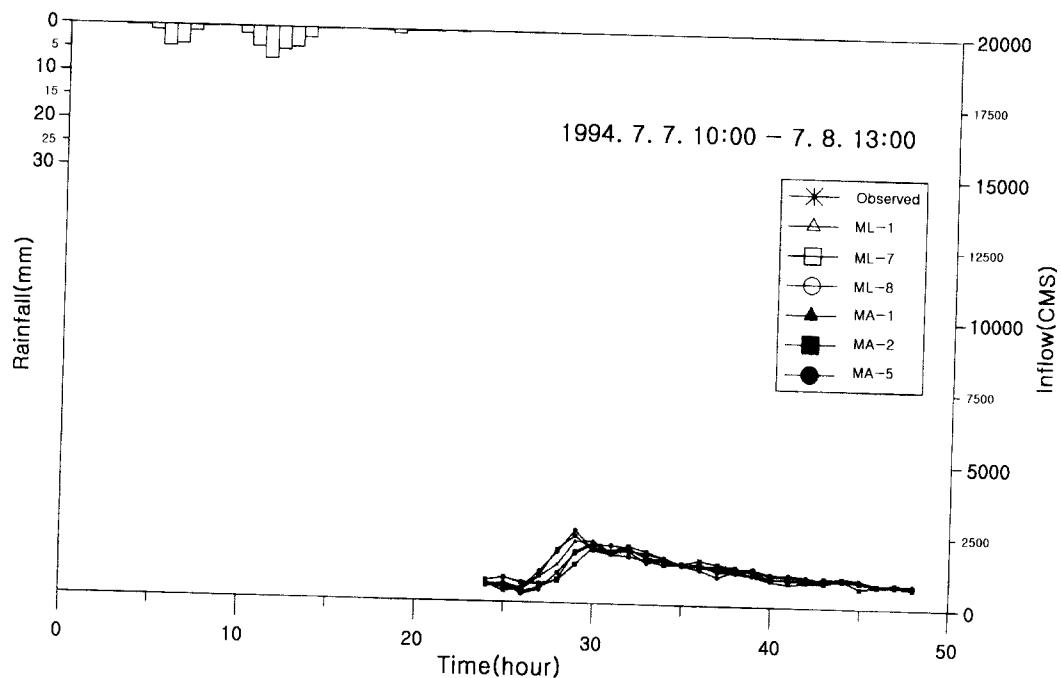


그림 10. 1994. 7. 07. 10:00 – 7. 08. 13:00 기간의 모의결과

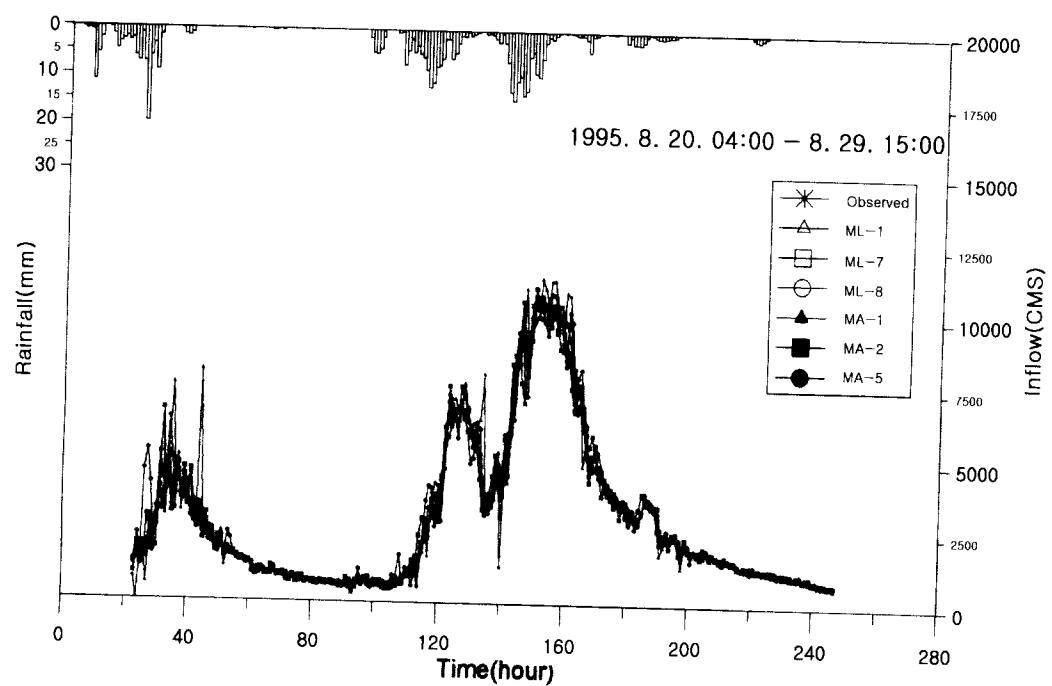


그림 11. 신경망모형의 예측 결과

표 4. 예측모형의 통계분석 결과

구분	RMSE	R <sup>2</sup>	CC
LM-1	0.0356	0.964	0.982
LM-7	0.0492	0.951	0.971
LM-8	0.0587	0.917	0.955
MA-1	0.0291	0.973	0.989
MA-2	0.0296	0.971	0.988
MA-5	0.0286	0.972	0.987

것으로 나타났으며, 그림 11에서 보듯이 overfitting 되는 결과를 나타내었다.

그 원인은 본 연구에서 사용한 출력 함수인 시그모이드 함수의 특성상 결과로 나타난 것이다.(Smith, 1993) 그리고 초기값의 불안정으로 정도가 떨어지는 것을 볼 수 있으며 이 문제를 해결하는 방법을 개발해야 될 것으로 사료된다. 전체적으로 그림 11과 표 4에 나타난 결과를 종합하여 볼 때 다목적 저수지 홍수유입량 예측을 위한 신경망모형의 적용은 대단히 만족스러운 것으로 판단된다. 예측 결과로부터 방법①과 방법②는 커다란 효율 차이는 없는 것으로 나타났으나, 학습 시간은 방법①보다 방법②가 오랜 시간이 걸렸으며, 학습 회수는 방법②가 방법①에 비해 매우 적게 나타났다. 그리고 은닉층 노드수는 방법①은 4/5N 일때와 방법②에서는 1N과 3N일 때 좋은 결과를 나타내었다. 이 결과는 최적화를 찾는 방법의 특성으로 판단된다. 그리고 방법②는 방법①에 비해 지역 최소최대값에 많이 빠지는 경향을 보이는데 이에 대한 해결 방법을 찾아야 될 것이며, 많은 연속적인 자료가 구축이 되면 보다 나은 예측 결과를 얻을 수 있을 것이다.

## 5. 결 론

충주댐 유역에 신경망이론을 적용한 홍수유입량 예측모형을 구축하였으며 이로부터 얻은 결론은 다음과 같다.

(1) 적용된 예측결과를 보면 결정계수와 상관계수의 정도로 판단할 때 복잡하고 비선형성이 강한 경우에 대한 저수지 홍수유입량 예측의 적용성이 매우 높은 것으로 나타났다.

(2) 예측결과로 Levenberg-Marquardt 방법과 모멘트와 적응학습률 방법을 비교하면, 전자의 방법은 지역 최소·최대값에 빠지는 경향을 나타냈으나 첨두유입량이 잘 예측되는 것으로 나타났으며, 후자의 방법은 전체적으로 안정된 예측을 하는 것으로 나타났으나 첨두유입량에 과소추정하는 경향을 나타냈다.

(3) 은닉층노드는 전자의 경우 입력층노드의 4/5N, 후자의 경우는 1N과 3N일 때 좋은 결과를 얻었다.

(4) 학습횟수는 전자의 경우는 1,500번 이상일 때와 후자의 경우는 25,000번 이상일 때 SSE가 더 이상 변화하지 않았다.

앞으로 신경망 모형이 유입량예측에 적용하기 위한 문제점을 보완하기 위해서는 최적해의 탐색방법과 안정된 초기값 설정방법을 보완하고, 기존의 개념적 강우-유출모형과 비교·고찰이 되어야 할 것이다.

## 감사의 글

한국학술진흥재단의 '94 대학 부설 연구소 지원 과제 "하천 및 저수지의 수자원·수질 종합 최적 관리를 위한 의사 결정 전문가 시스템 개발"의 연구 성과 중 일부이며, 이에 한국학술진흥재단의 지원에 감사드립니다.

## 참 고 문 헌

- 김대수 (1994). 신경망 이론과 응용(I). 하이테크정보, pp. 17-34.
- 김주환 (1992). "페턴인식방법을 적용한 하천유출의 비선형 예측." *한국수문학회지*, 제 25권, 제3호, pp. 105-113.
- 김주환 (1993). 신경회로망을 이용한 하천유출량의 수학적 예측에 관한 연구. 박사학위 논문, 인하대학교, pp. 1-20.
- 심순보, 김만식, 심규철 (1997). "신경망이론에 의한 다목적 저수지의 홍수유입량 예측." '97년 한국수자원학회 학술발표회 논문집, 한국수자원학회, pp. 409-413.
- 오남선, 선우중호 (1996). "신경망이론에 의한 강우예측에 관한 연구." *한국수자원학회지*, 제29권, 제4호, pp. 109-118.
- 오경두, 전병호 (1994). "미계측 중소유역 유출 시뮬레이션을 위한 신경회로망모형의 적용." 제36회 수공학 연구발표회 논문집, 한국수문학회, pp. 317 ~323.
- 윤여창 (1995). 시계열자료에서 신경망이론의 적용. 박사학위논문, 성균관대학교, pp. 7-14.
- 한국수자원공사 (1992). 한강수계 충주저수지 시스템의 실시간 최적운영을 위한 의사결정지원시스템의 개발 연구보고서. 수자원-92-3-1, pp. 5-13.
- Anthony W.M. (1996). "Extendet rainfall-runoff modeling using aritificial neural networks." *Proc. of the 2nd International Conf. on*

- Hydroinformatics*, Hydroinformatics '96, Zurich, Switzerland, pp. 207-213.
- Demuth, H., and Beale, M. (1994). *Neural network toolbox : For use with MATLAB user's guide*, The Math Works Inc., pp. 5.1-5.38.
- Flood, I. and Kartam, N. (1994a). "Neural networks in civil engineering I: Principles and understanding." *J. of Computing in Civil Engineering*, ASCE, Vol. 8, No. 2, pp. 131-148.
- Flood, I. and Kartam, N. (1994b). "Neural networks in civil engineering. II: System and application." *J. of Computing in Civil Engineering*, ASCE, Vol. 8, No. 2, pp. 149-162.
- French, M.N., Krajewski, W.F. and Cuykendall R.R. (1992). "Rainfall forecasting in space and time using a neural network." *J. of Hydrology*, Vol. 137, pp. 1-31
- Haykin, S. (1994). *Neural networks: A comprehensive foundation*. Prentice Hall, pp. 36-41.
- Hsu, K.L., Gupta, H.V., and Sorooshian, S. (1995). "Artificial neural network modeling of the rainfall-runoff process." *Water Resources Research*, Vol. 31, No. 10, pp. 2517-2539.
- Nachimuthu, K., William, J.G., Darrell, W., and Bovee K. (1994). "Neural networks for river flow prediction." *J. of Computing in Civil Engineering*, ASCE, Vol. 8, No. 2, pp. 201-220.
- Rumelhart, D.E., Hinton, G.E., and Williams, R.J. (1986). "Learning internal representations by error back propagation." *Parallel distributed processing*, Edited by Rumelhart, D.E., McClelland, J.L. and PDP Research Group, Chapter 8, Cambridge, MA, MIT Press.
- Shim, S.B., Fontane, D.G., and Lee H.S. (1994a). "A decision support system for multi-purpose reservoir operations." *Proc. of 21st Annual Conf. of the Water Resources Planning & Management*, ASCE, pp. 299-302.
- Shim, S.B., Fontane, D.G., and Lee H.S. (1994b). "A decision support system for reassessing the operations of the Chungju reservoir system." *Proc. of 21st Annual Conf. of the Water Resources Planning & Management*, ASCE, pp. 303-306.
- Smith, M. (1993). *Neural networks for statistical modeling*. Van Nostrand Reinhold, New York, pp. 1-114

〈최종본 접수일 : 1997년 12월 15일〉